

文章编号 1004-924X(2025)09-1434-12

Micro LED 表面缺陷的快速高精度检测

赵天元^{1,2}, 董登峰^{1,2*}, 王国名^{1,2}, 王 博¹, 周维虎^{1,2}

(1. 中国科学院 微电子研究所, 北京 100029;

2. 中国科学院大学, 北京 100049)

摘要: 为了满足 Micro LED 缺陷检测对实时性和高精度的要求, 结合轻量化的设计和增强的特征提取能力, 提出了一种快速高精度的检测算法 LED-YOLO。该方法通过设计图像采集系统并结合多种数据增广策略, 模拟工业环境中的实际干扰, 增强了训练数据的多样性。针对 Micro LED 缺陷的低区分度问题, 提出了轻量级动态融合模块 (Lightweight Dynamic Fusion Module, LDFM), 该模块结合动态卷积、深度卷积和通道混合操作, 在保持模型轻量化的同时, 提升了特征表达能力。为了进一步加强缺陷区域的关注, 设计了增强协调注意力模块 (Enhanced Coordinate Attention Module, ECAM), 通过结合通道和空间注意力机制及残差连接, 增强了特征提取的准确性。最后, 考虑到 Micro LED 图像的纵横比变化较小, 引入动态聚焦机制, 提出了 DIoU_W 回归损失函数, 显著提高了模型的收敛速度和稳定性。实验结果表明, LED-YOLO 的检测准确率、召回率、mAP、F1 值均优于目前最先进的 YOLOv11s 模型, 在参数量减少 1.6 M 的情况下, 检测速度和检测精度均有明显提升, 可以有效满足实际 Micro LED 面板制造过程的质量检验需求。

关键词: 深度学习; Micro LED; 缺陷检测; 动态卷积; 注意力机制

中图分类号: TP394.1; TH691.9 **文献标识码:** A

doi: 10.37188/OPE.20253309.1434 **CSTR:** 32169.14.OPE.20253309.1434

Rapid and high-precision detection on surface defects of Micro LED

ZHAO Tianyuan^{1,2}, DONG Dengfeng^{1,2*}, WANG Guoming^{1,2}, WANG Bo¹, ZHOU Weihu^{1,2}

(1. Institute of Microelectronics, Chinese Academy of Sciences, Beijing 100029, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

* Corresponding author, E-mail: dongdengfeng@ime.ac.cn

Abstract: To address the demands for real-time and high-precision Micro LED defect detection, this study introduces LED-YOLO, a rapid and accurate detection algorithm that integrates a lightweight architecture with enhanced feature extraction capabilities. An image acquisition system was designed to simulate industrial interference, and various data augmentation techniques were employed to increase the diversity of training data. To overcome the limited discriminative power for Micro LED defects, a Lightweight Dynamic Fusion Module (LDFM) was developed, combining dynamic convolution, deep convolution, and channel mixing operations; this approach maintains model compactness while enhancing feature extraction. Furthermore, an Enhanced Coordinated Attention Module (ECAM) was proposed to improve de-

收稿日期: 2024-12-17; 修订日期: 2025-01-24.

基金项目: 国家重点研发计划资助项目 (No. 2021YFF0700304)

fect localization by integrating channel and spatial attention mechanisms alongside residual connections, thus refining feature extraction accuracy. Given the minimal aspect ratio variation in Micro LED images, a dynamic focusing mechanism was incorporated, and a DIOU_W regression loss function was introduced to accelerate convergence and improve robustness. Experimental results demonstrate that LED-YOLO surpasses the state-of-the-art YOLOv11s in detection accuracy, recall, mean average precision (mAP), and F1 score. Despite a reduction of 1.6 million parameters, LED-YOLO achieves substantial improvements in detection speed and accuracy, effectively fulfilling the quality inspection requirements of Micro LED panel manufacturing.

Key words: deep learning; Micro LED; defect detection; dynamic convolution; attention

1 引言

Micro LED是一种新兴的显示技术,由微型发光二极管组成,以高亮度、宽色域和低功耗等优点,正迅速成为显示技术的主流选择。与传统液晶显示屏(LCD)和有机发光二极管显示屏(OLED)相比,Micro LED显示屏不仅在亮度和对比度上具备显著优势,还在响应速度和发光效率等方面表现出色。除了在虚拟现实眼镜、柔性屏幕等方面的应用外,Micro LED的小尺寸和高光谱使其在可见光通信、光学探测^[1]等领域也具有巨大的潜力。然而,Micro LED的生产过程中面临着诸多挑战,其中最突出的是生产过程中各种缺陷的有效检测。由于Micro LED的尺寸极小,通常在50 μm以下^[2],并且制造工艺复杂,生产中常常会出现如表面异物、金属泄露、边缘缺陷或膜层破损等缺陷。这些缺陷不仅影响最终产品的显示效果,还会降低产品良率,导致生产成本上升。为了提高Micro LED的生产效率和质量,开发一种实时、准确的Micro LED缺陷检测方法已成为关键需求。

早期的Micro LED缺陷检测方法主要有自动光学检测和人工视觉检测^[3-4]。自动光学检测利用各种光学成像设备对Micro LED芯片进行扫描,并通过模板匹配算法分析图像中的缺陷。翁伟汉等^[5]使用尺度不变特征变换(SIFT)和Harris-Laplace方法搜索LED芯片图案上的特征区域,对不同尺寸的LED以及LED芯片的外观缺陷进行定位。虽然在某些情况下能有效地识别缺陷,但在处理旋转、缩放以及复杂背景时的表现较差,检测精度较低。人工视觉检测则依

赖于操作员的经验,通过观察放大后的图像来判断缺陷。尽管这种方法灵活性较强,可以根据不同的缺陷类型调整检测策略,但其效率低下,且容易受到操作员疲劳和主观判断的影响,检测结果不准确。总体而言,这些传统的Micro LED缺陷检测方法在检测精度、实时性和稳定性方面均存在一定的局限性^[6]。

近年来,深度学习技术因其自动学习特征,准确率高,泛化能力强等特点而得到了广泛的应用,尤其在Micro LED表面缺陷检测方面取得了显著的进展。主流的深度学习检测框架有以Faster R-CNN为代表的两阶段网络和以YOLO(You Only Look Once)系列网络为代表的单阶段网络^[7]。其中,单阶段网络直接提取图片特征,可以实现在线、实时检测,在检测速度和计算效率方面更有优势。陈思翰等^[8]在YOLOv3的基础上融入密集连接卷积网络(DenseNet),并应用在表面贴装LED的缺陷检测中,YOLOv3-dense的平均精度(mean Average Precision, mAP)比YOLOv3高14.98%。陈美云等^[9]提出了一种改进YOLOv5s的AMS-YOLO网络,对残差模块、特征提取模块进行改进,并引入SE注意力机制,与YOLOv5s相比,AMS-YOLO表现出更好的性能,平均精度(mAP)、准确率(Precision)、召回率(Recall)和速度分别提高了3.0%,3.5%,6.0%和4.3%。钟泽邦等^[10]提出了一种CM-YOLOv5网络来检测Micro LED芯片缺陷,引入MA-Bottleneck瓶颈模块和类别平衡损失CB-BCE Loss,CM-YOLOv5的平均精度(mAP)提升了3.8%,准确率(Precision)提升了3.7%。YOLOv11s模型^[11]通过

引入新的跨阶段局部网络模块 C3k2, 是当下目标检测领域的最优检测模型。除了 YOLO 系列模型之外, 单阶段网络还有 SSD (Single Shot MultiBox Detector) 模型^[12] 和 RetinaNet 模型^[13]。刘松涛等^[14] 提出了一种引入 Receptive Field Block (RFB) 模块的 RFB-SSD 算法, 通过模拟人类视觉的感受野来加强网络的特征提取能力, 在 PASCAL VOC 数据集上实现了 82.2% 的 mAP。Paul 等^[15] 提出了 Retina U-Net 算法, 将 U-Net 嵌入 RetinaNet 模型中, 弥补了 RetinaNet 仅利用边界框级别监督所带来的信息损失, 改进后模型的平均精度 (mAP) 提高了 2%。

由于 Micro LED 表面缺陷检测中目标的小尺寸、大数量和低区分度等特性, 现有的检测模型性能都不太理想。针对自动光学检测的普适性不足和人工视觉检测的低效率问题, 本文基于 YOLOv11s 框架针对 Micro LED 表面缺陷检测提出 LED-YOLO 算法, 设计了 Micro LED 表面缺陷采集系统, 制作 Micro LED 缺陷数据集, 针对难以采集大量含缺陷 Micro LED 图像样本的问题, 提出了模拟生产环境变化的数据集增强策略。针对不同缺陷的特征差异, 提出一种轻量级动态融合模块 (Lightweight Dynamic Fusion Module, LDFM), 加强模型的多尺度

特征融合能力。为了进一步提升模型的特征提取能力, 提出增强协调注意力模块 (Enhanced Coordinate Attention Module, ECAM), 让模型更加关注有效信息。考虑 Micro LED 数据集特点提出回归损失函数 $DIoU_W$, 进一步提高检测精度和收敛速度。该算法能够实现 Micro LED 表面缺陷的快速高精度检测。

2 LED-YOLO 模型

本文提出的 LED-YOLO 算法总体结构主要由特征提取网络, 特征融合网络和检测头 3 部分组成, 如图 1 所示。

在 Backbone 中对输入图片分别进行 8 倍、16 倍和 32 倍的下采样, 完成多尺度特征提取, 在特征提取之后插入 ECAM 注意力模块用于关注缺陷区域, 之后作为 Neck 的三层输入。Neck 通过特征金字塔不同级别的信息融合, 提高多尺度特征的捕获能力。在 Backbone 和 Neck 中采用 LDFM 模块, 提高模型的特征提取能力。最后, 从 Neck 获得的 3 个不同尺寸和不同通道数量的特征图, 输入 Head 中进行预测计算, 采用新的回归损失函数 $DIoU_W$, 提升 Micro LED 表面缺陷检测的精度和速度。




图1 LED-YOLO网络模型结构

Fig. 1 Structure of LED-YOLO network model

2.1 轻量级动态融合模块

为了在保持特征提取能力的同时提高模型的检测效率,本文在动态卷积^[16]的基础上设计了LDFM,并集成在YOLOv11s网络的Backbone和Neck部分。LDFM通过结合动态卷积和深度卷积,保留了强大的特征表达能力,同时显著降低了计算成本和模型参数量。该模块的结构如图2所示,能够在显著减少计算复杂度的同时,保持高检测准确度,尤其适用于对计算效率和轻量化设计要求高的Micro LED表面缺陷检测任务。




图2 LDFM结构

Fig. 2 Structure of LDFM

LDFM的设计充分考虑了Micro LED缺陷图像的典型特点,即检测目标密集且尺寸变化较小。由LDFM的结构可知:第一,模块采用残差结构,缓解了梯度消失问题,从而使网络能够灵活地学习复杂特征;第二,引入动态卷积操作,增强模型对不同缺陷形态的识别能力,提高模型的泛化能力;第三,采用深度卷积以减少模块的参数数量和计算复杂度,达到轻量化的目的;第四,添加通道混合操作增强通道之间的信息交互能力,进一步提升了特征表达的效果。

动态卷积是对传统卷积操作的拓展,允许网

络根据输入自适应地调整其参数。通过对每个输入样本动态地选择和组合不同的卷积核来增加模型的特征表达能力,这种选择通过注意力机制来实现,如图3所示。给定的输入特征 $Input(x)$ 经过一个注意力网络,包含池化层、扁平化操作、全连接层和激活函数,动态计算得出每一个卷积核的权重,输出 $Output(y)$ 是所有卷积操作的加权和,计算过程如下:

$$Output(y) = \sum_{i=1}^K w_i [Input(x) * Conv_i], \quad (1)$$

其中: w_i 是动态权重,*是卷积操作, $Conv_i$ 是卷积核。通过这种方式,模型能够根据输入特征动态选择最合适的卷积核,增强特征表达能力,从而更好地适应Micro LED缺陷检测任务中的多样化特征。




图3 动态卷积

Fig. 3 Dynamic convolution

在LDFM中,深度卷积代替传统的标准卷积,通过对每个输入通道独立进行卷积,能够大幅度减少计算复杂度和参数量,使得模型更加轻量化,进一步优化计算效率。标准卷积和深度卷积的参数数量计算公式如下:

$$N = C_1 \times k \times k \times C_2, \quad (2)$$

$$N_{dw} = C_1 \times k \times k \times 1, \quad (3)$$

其中: N 是标准卷积的参数数目, N_{dw} 是深度卷积的参数数目,输入通道数为 C_1 ,输出通道数为 C_2 ,卷积核大小为 k 。由此可得,深度卷积的参数数目是标准卷积的 $\frac{1}{C_2}$ 。因此,通道数越多,深度卷积的参数就越少。

LDFM还增加了通道混合操作,可以进一步增强通道之间的特征交互能力,提升模型的特征表达能力,有效提高模型在不同缺陷类型上的检测精度。

2.2 增强协调注意力

注意力机制^[17]可为输入信息赋予不同的权

重,从而增强模型对弱特征的关注和捕捉能力,进而提升网络性能,而无需加深网络的深度。尤其在目标检测任务中,注意力机制已成为提高模型精度和稳定性的重要工具。Micro LED 缺陷图像通常具有缺陷区域大小不一、形态多样的特点,以及高密度和多尺度的特征,模型需要在多

个尺度上有效地捕捉局部特征。针对这些挑战,本文提出了 ECAM,如图 4 所示。该模块结合通道信息和空间信息,能够更好地捕捉 Micro LED 缺陷图像中的全局上下文和局部关键特征,从而显著提升模型在低对比度和高密度缺陷场景中的检测性能。




图 4 增强协调注意力模块结构

Fig. 4 Structure of enhanced coordinate attention module

ECAM 输出 Y 的计算过程分为 4 部分。

(1) 通道注意力 Y_{Channel} , 通过全局平均池化对输入特征图进行降维, 得到每个通道的全局描述向量 $(C, 1, 1)$, 对该向量应用一维卷积, 引入局部依赖, 从而生成更精细的通道注意力, 之后再经过 Sigmoid 激活函数输出, 得到:

$$Y_{\text{Channel}} = \text{Sigmoid}(\text{Conv1d}(y_{\text{Channel}})), \quad (4)$$

$$y_{\text{Channel}} = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W X[:, :, h, w]. \quad (5)$$

(2) 空间注意力 Y_{spatial} , 通过降维操作将输入特征图的通道数减少至 C_1 , 得到一个轻量化的特征图 Z 以降低计算复杂度, 接着基于高度和宽度两个维度分别求平均计算得到水平方向特征 X_h 和垂直方向特征 X_w , 再通过两个 1×1 卷积和 Sigmoid 激活函数后, 生成两个注意力图 y_h 和 y_w , 最终得到:

$$Z = \text{Gelu}(\text{BN}(\text{Conv2d}(X))), \quad (6)$$

$$X_h = \frac{1}{W} \sum_{w=1}^W Z[:, :, :, w], \quad (7)$$

$$X_w = \frac{1}{H} \sum_{h=1}^H Z[:, :, h, :], \quad (8)$$

$$y_h = \text{Sigmoid}(\text{Conv2d}(X_h)), \quad (9)$$

$$y_w = \text{Sigmoid}(\text{Conv2d}(X_w)), \quad (10)$$

$$Y_{\text{spatial}} = y_h \cdot y_w. \quad (11)$$

(3) 通道注意力与空间注意力融合, ECAM 通过学习参数动态调整两者融合的权重比例, 以适应不同的任务需求, 最终得到:

$$Y_{\text{atten}} = \alpha \cdot Y_{\text{spatial}} + \beta \cdot Y_{\text{Channel}}. \quad (12)$$

(4) 残差连接, ECAM 通过 1×1 卷积调整输入特征的通道数, 并与融合后的注意力 Y_{atten} 相乘。通过残差连接, 模块保留了输入信息的完整性, 从而增强了模型对特征的区分能力, 最终输出为:

$$Y = Y_{\text{atten}} \cdot \text{Conv2d}(X) + X. \quad (13)$$

通过上述设计, ECAM 专注于联合提取通道信息和空间信息。通过全局建模通道维度信息与局部建模空间维度信息, ECAM 能够更有效地捕捉 Micro LED 缺陷图像中的全局上下文和局部低区分度的重要特征。同时, 动态权重自适应

提升了模块通用性,能够根据不同的任务需求自动调整注意力的权重比例;残差连接则保持了输入信息的完整性,避免了梯度消失问题,从而提升了模型的检测精度。

2.3 DIoU_W 损失函数

在目标检测任务中,边界框回归是确保模型准确定位目标的关键步骤之一。近年来,针对目标检测任务的定位精度和收敛速度问题,许多基于交并比(Intersection over Union, IoU)的损失函数相继被提出。YOLOv11s中使用CIoU^[18]作为IoU的度量,引入预测框和真实框的中心点距离和宽高比作为惩罚项,从而优化模型的性能。然而,尽管CIoU在很多任务中表现良好,但在处理Micro LED数据集时仍然存在一些局限性。在该数据集中,待检测的目标数量庞大,但目标的纵横比变化较小,这使得纵横比对模型收敛的贡献有限,甚至可能影响模型的收敛速度。此外,由于数据集是人工标注的,标注质量参差不齐,低质量的标注样本会对模型精度产生负面影响。

为了解决这些问题,本文提出了DIoU_W损失函数,结合DIoU^[18](Distance IoU)的收敛速度优势和WIoU^[19](Wise IoU)的精度优势,从而有效地解决了现有损失函数在Micro LED图像数据集上的不足。DIoU通过仅考虑预测框与真实框的中心点距离来加速模型的收敛过程,舍弃了纵横比惩罚项,从而提升了模型的性能。WIoUv3的动态非单调聚焦机制确保了模型在收敛过程中始终能够保持动态的最优梯度,从而进一步提升了整体检测性能。

DIoU_W损失函数的定义如下:

$$DIoU_W = DIoU * R_{WIoU}, \quad (14)$$

其中:DIoU通过引入框的中心点距离来优化传统IoU的不足,同时舍弃了纵横比惩罚项,以加速模型的收敛过程。其表达式如下:

$$DIoU = IoU - \left(\frac{\rho^2(b, b_{gt})}{c^2} \right), \quad (15)$$

式中: b 和 b_{gt} 分别代表预测框和真实框的中心点; ρ 代表两个中心点间的欧氏距离; c 代表能够同时包含预测框和真实框的最小矩形区域的对角线长度。通过去除纵横比惩罚项,DIoU能够更快速地优化框的位置,从而加速模型的收敛。

R_{WIoU} 是WIoUv3的动态调整系数,用于表示

样本的权重,能够根据样本的难易程度动态调整损失函数,从而提高模型在困难样本上的表现。通过引入 R_{WIoU} ,损失函数能够灵活调整每个样本的权重,确保在训练过程中模型能够关注那些对最终性能影响更大的样本,从而避免忽视困难样本。 R_{WIoU} 的计算公式为:

$$R_{WIoU} = \frac{\beta}{\delta \alpha^{\beta - \delta}}, \quad (16)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}}, \quad (17)$$

其中: β 定义为离群度,衡量样本与其他样本的差异; δ 和 α 为两个超参数,用于调整权重系数; L_{IoU}^* 表示从计算图中分离 L_{IoU} ,不参与梯度计算; L_{IoU} 为 L_{IoU} 的均值^[19]。通过这些调整,损失函数能够根据每个样本的难度进行灵活的调整,进一步提高模型对困难样本的适应能力。

3 实验

3.1 实验数据集制作

实验数据来自图5所示的Micro LED缺陷检测系统,图像采集部分由iDS相机、显微镜镜头、白色光源和上位机组成,运动控制部分由索雷博二维扫描位移模块及其控制器组成。Micro LED晶圆样品放置在二维扫描位移模块上,该模块行程为110 mm×75 mm,最小位移量为0.1 μm,重复精度为0.25 μm,通过控制器控制其运动;iDS相机分辨率为4 000×3 000,像素尺寸为1.85 μm,通过10×显微镜镜头获取Micro LED的图像数据,由




图5 Micro LED缺陷采集系统

Fig. 5 Micro LED defect collection system

上位机接收和显示,最终确定 151 张图像并使用 LabelImg 软件进行手动标注,得到原始数据集。

如表 1 所示, Micro LED 芯片分为 5 种类型: Normal(正常)、Foreign-matter(异物)、Metal-leak(金属泄漏)、Edge-defect(边缘缺陷)和 Coating-broken(膜层破损),其中 4 种缺陷如图 6 所示。不同的芯片缺陷类型有不同的颜色特征、形状特征,以及纹理特征。考虑到实际生产过程中的各种工业干扰,如粉尘颗粒、照明变化、振动等,同时为了提高模型的泛化能力,本文选择翻转图像、添加随机噪声和改变图像亮度的数据增强方法,来模拟生产环境变化所带来的影响。增强后的数据集包含 906 张图像,共计 122 922 个 Micro LED 芯片,以 7:1:2 的比例分为训练集、验证集和测试集。




图 6 Micro LED 图像和缺陷芯片的放大视图
Fig. 6 Enlarged images of defects and normal image of Micro LED

表 1 Micro-LED 数据集的缺陷类别和数量

Tab. 1 Defect categories and quantities in Micro LED dataset

Category	Normal	Foreign-matter	Metal-leak	Edge-defect	Coating-broken
Train	69 350	5 830	3 771	1 941	4 505
Val	10 045	916	504	401	467
Test	21 717	1 736	662	468	609
Total	101 112	8 482	4 937	2 810	5 581

表 1 为每个类别的样本数量分布情况。

3.2 实验环境及评价指标

实验配置如下: CPU 为 Intel(R) Core(TM) i9-10980XE CPU @ 3.00 GHz, GPU 为 NVIDIA GeForce RTX 3090, 24 GB 内存。软件环境包括 Python 3.8.19, torch-2.4.0, CUDA11.8。输入图像分辨率统一调整为 640 像素×640 像素,以减少计算量,提高检测速度。在网络模型训练的过程中,使用 AdamW 优化器,将动量和权重衰减设置为 0.9 和 0.000 5,批量大小设置为 32,训练时期设置为 500。

本文采用准确率(Precision, P)、召回率(Recall, R)、平均精度均值(mean Average Precision, mAP)、F1 分数、模型参数量(M)和每秒帧数(FPS)作为评价指标来评估模型的性能。准确率和召回率的公式如下:

$$P = \frac{TP}{TP + FP}, \quad (18)$$

$$R = \frac{TP}{TP + FN}, \quad (19)$$

其中: TP 表示正样本预测为正的数; FP 表示正样本预测为负的数量,即误报数; FN 表示负样本预测为正的数,即漏检数。平均精度均值是不同待检测类别平均精度的均值,见式(20),其值越高,检测效果越好。

$$mAP = \frac{1}{N} \sum_{i=1}^N \int_0^1 P(R) dR, \quad (20)$$

其中 N 为缺陷的类别数。F1 分数通过准确率和召回率来评估模型的平衡性能,值越高表示模型的整体性能越好,能够在精准度和召回率之间取得良好的平衡。其公式为:

$$F1 = \frac{2 \times P \times R}{P + R}. \quad (21)$$

3.3 实验结果及分析

LED-YOLO 模型在 YOLOv11s 的基础上进行改进,保留了 YOLOv11s 的网络结构,在 Backbone 和 Neck 网络中对深层次特征采用 LDFM 模块,并且将新的注意力模块 ECAM 引入到 Backbone 中,同时采用 DIOU_W 参与回归损失函数的计算。

3.3.1 LED-YOLO 模型实验结果

为了验证所提出的模型的检测性能,对 Micro LED 数据集进行测试,结果如表 2 所示。从实验结果可以看出, LED-YOLO 模型对 5 类芯片

中除异物类型的其他 4 类芯片的检测准确率和召回率均达到了 97% 以上,平均精度均值表现出色。不过,异物类缺陷的检测效果相较于其他类型较差。其原因在于异物类属于较难检测的缺陷类型,具有形状不规则、尺寸变化大的特征。这种不规则性和尺寸的不确定性使得模型在学习和检测该类缺陷的特征时面临较大挑战,导致检测出现一定的误差,从而使其召回率仅为 90.1%,低于其他类型缺陷。

表 2 LED-YOLO 实验结果

Tab. 2 Experiment results of LED-YOLO (%)

Category	P	R	mAP
Normal	99.1	99.5	99.4
Foreign-matter	97.9	90.1	98.0
Metal-leak	98.8	97.4	99.4
Edge-defect	97.7	98.6	99.5
Coating-broken	99.0	99.2	99.5
All	98.5	96.9	99.2

3.3.2 不同模型实验对比

为了对比分析所提出的 LED-YOLO 模型的性能,本文选择单阶段网络中具有代表性和广泛使用的检测模型,在 Micro LED 数据集上进行比较实验,包括 SSD, RFB-SSD, RetinaNet, Retina U-Net, YOLOv5s, YOLOv6s, YOLOv8s, YOLOv8s-p2, YOLOv9s, YOLOv10s 和 YOLOv11s。表 3 给出了不同网络模型的性能指标,

其中,本文提出的 LED-YOLO 网络在许多指标上都优于 YOLO 系列其他网络,也是唯一 mAP 超过 99% 的模型。

LED-YOLO 的准确率和 mAP 分别达到了 98.5% 和 99.2%,相比于 YOLOv5s (96.4% 和 97.4%), YOLOv8s (95.7% 和 97.5%), YOLOv11s (97.5% 和 97.3%) 模型有大幅度提升。这是因为 LED-YOLO 模型在特征提取和注意力机制上的改进, LDFM 和 ECAM 提高了对多目标和难检测缺陷的检测能力,尤其是在边缘区域或者细节较少的区域,都表现出较高的敏感性。

在检测速度方面, LED-YOLO 达到了 212 frame/s。相较于其他模型,特别是 SSD (59 frame/s), RFB-SSD (45 frame/s), RetinaNet (41 frame/s), Retina U-Net (33 frame/s), LED-YOLO 能够在保持高精度的同时,实现检测速度的较大提升。其原因是引入 LDFM 和 DIoU_W 损失函数,前者可以在降低计算成本和复杂度的同时,保留强大的特征表达能力;后者则可以在快速收敛时兼顾精度要求。

在准确率和召回率之间的平衡方面, LED-YOLO 也表现出色。其 F1 分数为 97.69%, 相较于 YOLOv6s (89.42%) 提升显著,表明 LED-YOLO 在面对难检测缺陷时,表现更加稳定。在参数量方面, LED-YOLO 通过引入 LDFM 实现了较低的参数量 7.8 M, 与 YOLOv6s (16.0 M)、YOLOv8s (11.1 M) 和 YOLOv8s-p2 (10.6 M) 相

表 3 不同模型的实验结果

Tab. 3 Experimental results of different models

Model	P (%)	R (%)	mAP (%)	F1 (%)	Params(M)	FPS
SSD	85.6	86.8	87.4	86.20	24.7	59
RFB-SSD	89.1	90.3	88.9	89.70	25.4	45
RetinaNet	91.4	87.9	89.1	89.62	36.5	41
Retina U-Net	91.6	89.9	90.7	90.74	38.0	33
YOLOv5s	96.4	97.1	97.4	96.75	9.1	117
YOLOv6s	96.5	83.3	86.6	89.42	16.0	158
YOLOv8s	95.7	96.9	97.5	96.30	11.1	78
YOLOv8s-p2	96.2	97.2	96.6	96.70	10.6	163
YOLOv9s	96.0	96.0	97.1	96.00	7.2	121
YOLOv10s	97.8	93.0	97.6	95.34	8.1	256
YOLOv11s	97.5	92.8	97.3	95.09	9.4	200
LED-YOLO(Ours)	98.5	96.9	99.2	97.69	7.8	212

比,LED-YOLO在减少计算开销的同时,不仅提高了检测精度,还增强了模型的实时性。

相较于 SOTA 模型 YOLOv11s,LED-YOLO 模型在参数量减少 1.6 M 的情况下,检测准确率、召回率、mAP 和 F1 值分别提升了 1%,4.1%,1.9%,2.6%,检测速度更是提高了 6%,在高精度和实时性之间找到了平衡点。

本文选择 RetinaNet, YOLOv8s 和 YOLOv11s 3 种检测模型与 LED-YOLO 进行比较,并将每个模型的漏检和误检情况进行放大展示,如图 7 所示(彩图见期刊电子版)。红色虚线圆圈内为漏检区域,由第一组图片可以看出,RetinaNet 和 YOLOv8s 在处理多目标图像检测时有较高的漏检率,YOLOv11s 在这方面表现尚可,但仍有遗漏。而 LED-YOLO 在检测小而多的 Micro LED 图像时表现良好,能对图像内的所有 Micro LED 芯片进行检测,避免漏检。绿色圆圈内为误检区域,可以看出所有模型对异物类型的缺陷都不

太敏感,这是因为该类缺陷是由 Micro LED 晶圆受到污染而产生的,缺陷存在随机性,具有形状不规则、尺寸变化大的特点。如第二组图片所示,面积较小的异物缺陷容易存在误检的情况,LED-YOLO 模型对这类缺陷的检测能力要优于其他 3 种模型。

综上,LED-YOLO 在准确率、召回率和 F1 分数等关键指标上表现卓越,并且实现了较低的参数量和显著的推理速度提升,充分满足 Micro LED 表面缺陷检测的高精度需求与实时性要求。

3.3.3 不同损失函数实验对比

本文采用 LDFM+ECAM 的网络模型,将 $DIoU_W$ 与 $DIoU$, $GIoU$, $EIoU$, $SIoU$ 和 $WIoU$ 进行了实验对比,探究不同损失函数对模型检测性能的影响,结果如表 4 所示。实验结果表明,采用 $DIoU_W$ 作为损失函数时,mAP 和 F1 分数分别达到了 99.2% 和 97.69%,是所有损失函数中最高的;FPS 指标也达到了 212,展现出一定的优势。




图 7 不同模型的检测结果比较

Fig. 7 Comparison of detection results of different models

在 Micro LED 检测任务中,采用 $DIoU$ 作为损失函数时 FPS 指标为 222,明显高于其他损失函数。这是因为 $DIoU$ 通过舍弃纵横比的惩罚项来简化计算,能够加速模型的收敛过程,收敛速度较快。然而, $DIoU$ 的 F1 分数为 92.67%,仅高

于 $GIoU$,说明 $DIoU$ 仍存在一定的精度提升空间。采用 $WIoU$ 作为损失函数时有较高的精度,mAP 为 98.5%,F1 分数为 95.60%,仅次于 $DIoU_W$,其原因为 $WIoU$ 的动态非单调聚焦机制使得模型能够更好地聚焦较难检测的样本。但

表 4 不同损失函数的实验结果

Tab. 4 Experimental results of different loss functions

Method	mAP(%)	F1(%)	FPS
Our work+DIoU	98.8	92.67	222
Our work+GIoU	96.4	91.52	185
Our work+EIoU	97	94.57	217
Our work+SIoU	98.7	95.15	212
Our work+WIoU	98.5	95.60	144
Our work+DIoU_W	99.2	97.69	212

是 WIoU 的 FPS 较低,仅为 144,限制了 Micro LED 缺陷检测任务的实时性。

DIoU_W 通过结合 DIoU 的快速收敛性和 WIoU 的精度优势,表现出较高的精度和计算效率。采用 DIoU_W 作为损失函数时,mAP 为 99.2%,FPS 为 212,显示出 DIoU_W 在 Micro LED 缺陷检测任务中的明显优势。

实验结果验证了 DIoU_W 损失函数在 Micro LED 缺陷检测任务中的有效性。与现有损失函数相比,DIoU_W 损失函数在目标密集且标注质量较低的场景中,显示出明显的优势,在实际 Micro LED 缺陷检测应用中具有巨大潜力。

3.3.4 消融实验

为了证明所提出 LDFM,ECAM 和 DIoU_W 的必要性,并分析每个模块对 LED-YOLO 模型性能的影响,本文进行了消融实验,结果如表 5 所示。第一行为基准模型 YOLOv11s(未添加任何模块),在 mAP 和 F1 分数上分别达到 97.3% 和 95.09%,推理速度为 200 FPS,参数量为 9.4 M。

首先,引入 LDFM 模块后,mAP 提升至

表 5 三种改进方式的消融实验

Tab.5 Ablation experiments of three improvement approaches

LDFM	ECAM	DIoU_W	mAP/%	F1/%	Params/M	FPS
—	—	—	97.3	95.09	9.4	200
✓			98.2	96.95	8.3	200
	✓		98.6	97.24	9.0	217
		✓	97.7	95.05	9.4	217
✓	✓		98.7	97.49	7.8	222
✓		✓	98.5	96.09	8.3	212
	✓	✓	98.2	97.04	9.0	222
✓	✓	✓	99.2	97.69	7.8	212

98.2%,F1 分数上升至 96.95%,参数量减少至 8.3 M,推理速度保持不变。这表明 LDFM 有效增强了特征提取能力,同时减少了模型复杂度。其次,单独引入 ECAM 模块时,mAP 提升至 98.6%,F1 分数达到 97.24%,推理速度增加到 217 frame/s,参数量变化较小。这说明 ECAM 模块在增强注意力机制的同时,提高了推理效率。最后,仅添加 DIoU_W 模块时,mAP 为 97.7% 提高了 0.4%,推理速度提升至 217 frame/s,表明 DIoU_W 提升少量精度的同时可以提高模型的收敛速度。

当同时引入 LDFM 和 ECAM 模块时,mAP 达到 98.7%,F1 分数为 97.49%,推理速度提升至 222 frame/s,参数量显著降低至 7.8 M,进一步证明两者的协同作用能够提升性能并减小模型规模。ECAM 与 DIoU_W 的结合使 mAP 达到 98.2%,F1 分数提升至 97.04%,推理速度为 222 frame/s,参数量为 9.0 M,这表明两模块对检测精度和推理效率的平衡优化。

最后,同时引入 LDFM,ECAM 和 DIoU_W 3 个模块时,模型性能达到最佳,mAP 和 F1 分数分别提升至 99.2% 和 97.69%,参数量为 7.8 M,推理速度为 212 frame/s。这一结果表明,三者的结合能够在保证高精度的同时兼顾效率,LED-YOLO 模型的准确性和效率达到平衡。

另外,本文展示了 LED-YOLO 模型在决策过程中的热力图变化,如图 8 所示。从可视化结




图 8 不同方法的热力图比较

Fig. 8 Comparison of heatmap of different methods

果可以看出:随着引入 LDFM, ECAM 和 DI-oU_W 模块,增加了网络模型对输入图像关键区域的关注度,可以提高检测准确率。

4 结 论

本文提出了基于机器视觉的 LED-YOLO 算法,用于 Micro LED 表面缺陷的实时、高效、精准检测。通过设计图像采集系统并结合多种数据增强策略,显著提升了模型的泛化能力。针对 Micro LED 缺陷的不同特性,提出 LDFM;为解决缺陷区域区分度低的问题,提出 ECAM;针对数据集特性和实际检测需求,设计了回归损失函数(DI-oU_W)。实验结果表明,LED-YOLO 在检测准确率(98.5%)、召回率(96.9%)、mAP(99.2%)和 F1 值(97.69%)等指标均优于现有最先进的 YOLOv11s 模型,并且检测速度提高了 6%。

尽管如此,LED-YOLO 在处理异物缺陷时仍存在一定的挑战。未来的研究重点如下:首

先,通过优化模型结构、实现轻量化设计以推理速度,从而满足 Micro LED 表面缺陷实时检测的要求;其次,进一步改进特征融合模块(LDFM)和注意力模块(ECAM),增强对形状随机、尺寸多样的缺陷特征提取能力,保证检测精度;最后,探索多模态数据融合检测技术,结合视觉、红外、荧光光谱等多种数据源,以应对更加复杂的工业场景,进一步提升模型在各种环境下的稳定性和准确性。

作者贡献声明:

赵天元:论文构思,实验研究,数据处理,初稿写作;

董登峰:提供资源,实验指导,论文审阅与修订;

王国名:调查研究,实验指导,论文审阅与修订;

王博:提供资助,实验指导;

周维虎:实验指导。

参考文献:

- [1] JAMES SINGH K, HUANG Y M, AHMED T, *et al.* Micro-LED as a promising candidate for high-speed visible light communication[J]. *Applied Sciences*, 2020, 10(20): 7384.
- [2] WU T, SHER C W, LIN Y, *et al.* Mini-LED and micro-LED: promising candidates for the next generation display technology [J]. *Applied sciences*, 2018, 8(9): 1557.
- [3] ABD AL RAHMAN M, MOUSAVI A. A review and analysis of automatic optical inspection and quality monitoring methods in electronics industry [J]. *Ieee Access*, 2020, 8: 183192-183271.
- [4] 苏昊,李文豪,李俊龙,等. 晶圆级 Micro-LED 芯片检测技术研究进展[J]. *液晶与显示*, 2023, 38(5): 582-594.
- [5] SU H, LI W H, LI J L, *et al.* Recent progress of wafer level Micro-LED chip inspection technology [J]. *Chinese Journal of Liquid Crystals and Displays*, 2023, 38(5): 582-594. (in Chinese)
- [6] ZHU G, LIU Y, MING R, *et al.* Mass transfer, detection and repair technologies in micro-LED displays [J]. *Science China Materials*, 2022, 65(8): 2128-2153.
- [7] LI Z, WEI X, HASSABALLAH M, *et al.* A One-Stage Deep Learning Model for Industrial Defect Detection [J]. *Advanced Theory and Simulations*, 2023, 6(7): 2200853.
- [8] CHEN S H, TSAI C C. SMD LED chips defect detection using a YOLOv3-dense model [J]. *Advanced engineering informatics*, 2021, 47: 101255.
- [9] CHEN M, CHEN J, LI C, *et al.* Defect detection of MicroLED with low distinction based on deep learning [J]. *Optics and Lasers in Engineering*, 2024, 173: 107924.
- [10] ZHONG Z, LI C, CHEN M, *et al.* Micro LED defect detection with self-attention mechanism-based neural network [J]. *Digital Signal Processing*, 2024, 149: 104474.
- [11] GLENN J, QIU J. Ultralytics YOLO11 [EB/OL]. [2024-11-27]. <https://github.com/ultralytics/ultralytics>.
- [12] LIU W, ANGUELOV D, ERHAN D, *et al.* *facturing Technology*, 2021, 117: 3297-3321.

- Ssd: Single shot multibox detector[C]. *Computer Vision – ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11 – 14, 2016, Proceedings, Part I* 14. Springer International Publishing, 2016: 21-37.
- [13] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal loss for dense object detection[C]. *Proceedings of the IEEE international conference on computer vision*, 2017: 2980-2988.
- [14] LIU S, HUANG D. Receptive field block net for accurate and fast object detection[C]. *Proceedings of the European conference on computer vision (ECCV)*, 2018: 385-400.
- [15] QI Z, ZHANG M, LI J, *et al.* Improved retinanet-based defect detection for engine parts[C]. 2023 42nd Chinese Control Conference (CCC). IEEE, 2023: 7717-7722.
- [16] CHEN Y, DAI X, LIU M, *et al.* Dynamic convolution: Attention over convolution kernels [C]. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020: 11030-11039.
- [17] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2021: 13713-13722.
- [18] ZHENG Z, WANG P, LIU W, *et al.* Distance-IoU loss: Faster and better learning for bounding box regression[C]. *Proceedings of the AAAI conference on artificial intelligence*, 2020, 34 (7) : 12993-13000.
- [19] TONG Z, CHEN Y, XU Z, *et al.* Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. *Arxiv Preprint Arxiv*: 2301.10051, 2023.

作者简介:



赵天元(1996—),男,河南焦作人,博士研究生,2018年于吉林大学获得学士学位,主要从事精密检测方面的研究。E-mail: zhaotianyuan@ime.ac.cn

通讯作者:



董登峰(1981—),男,河南商丘人,博士,研究员,博士生导师,2004年于郑州大学获得学士学位,2012年于北京航空航天大学获得博士学位,主要从事光学精密测量、AI识别方法、智能跟踪控制、视觉伺服控制系统等方面的研究。E-mail: dongdengfeng@ime.ac.cn